

VGG16 Transfer Learning for Bone Fracture Classification Using X-Ray Images

Megan Febriana Putri Johana¹, Christy Atika Sari^{2*}

Teknik Informatika, Universitas Dian Nuswantoro

111202315039@mhs.dinus.ac.id¹, christy.atika.sari@dsn.dinus.ac.id^{2*}

Article Info

Article history:

Received 2026-04-08

Revised 2026-05-26

Accepted 2026-05-30

Keyword:

Bone Fracture,
X-Ray,
Deep Learning,
Transfer Learning,
VGG16

ABSTRACT

Bone fracture is one of the most common injury conditions and requires a fast and accurate diagnosis process to assist optimal medical treatment. Examination using X-Ray images is the main method in identifying bone fractures, but the process of interpreting radiographic images has challenges, especially in Multi-class classification with similar fracture characteristics. This study aims to implement a transfer learning method based on the VGG16 architecture for Multi-class classification of bone fractures using X-Ray images. The dataset used consists of 11 classes, namely Avulsion Fracture, Comminuted Fracture, Fracture Dislocation, Greenstick Fracture, Hairline Fracture, Impacted Fracture, Longitudinal Fracture, Oblique Fracture, Pathological Fracture, Spiral Fracture, and Normal. The preprocessing stage includes resizing the image to 256×256 pixels, RGB conversion, VGG16 preprocessing, and data augmentation to increase the variety of the dataset. The model was built using pretrained VGG16 as a feature extractor with the addition of GlobalAveragePooling2D, Dense layer, BatchNormalization, and Dropout and fine-tuning was performed on several final layers. The evaluation results showed that the model obtained an accuracy of 98.40%, a macro precision of 97.95%, and a macro recall of 97.95%. In addition, most classes obtained accuracy values close to 100%. The results showed that the application of VGG16-based transfer learning was able to provide excellent classification performance on X-Ray images of bone fractures and was effective in improving the model's generalization ability in multi-class classification of medical images.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Kecelakaan menjadi salah satu penyebab utama terjadinya cedera di Indonesia dan sering kali menyebabkan dampak yang serius bagi para korban. Berdasarkan data Badan Pusat Statistik (BPS) dalam publikasi *Statistik Transportasi Darat 2024*, jumlah kecelakaan lalu lintas di Indonesia dalam satu tahun mencapai 150.906 kasus. Kecelakaan tersebut mengakibatkan korban dengan berbagai tingkat kondisi parah, sebanyak 16.601 orang mengalami luka berat dan 183.995 orang mengalami luka ringan. Data ini menunjukkan bahwa sebagian besar korban kecelakaan didominasi oleh luka ringan, sementara korban luka berat jumlahnya relatif lebih sedikit dibandingkan total keseluruhan korban [1]. Mayoritas korban yang mengalami luka mempunyai risiko

tinggi terjadinya patah tulang (fraktur) yang merupakan salah satu akibat umum dari kecelakaan. Situasi ini memerlukan proses pengenalan cedera yang cepat dan akurat agar perawatan medis dapat dilaksanakan dengan efisien.

Fraktur atau patah tulang diartikan secara medis sebagai kondisi di mana terdapat kerusakan atau terputusnya kesinambungan struktural pada korteks tulang [2]. Kondisi ini mengakibatkan hilangnya kontinuitas tulang yang tidak merusak struktur keras, namun berdampak pada cedera jaringan lunak di sekitarnya, seperti kerusakan pada otot, saraf, hingga pembuluh darah [3]. Dalam praktik klinis, pengenalan jenis fraktur bergantung pada analisis manual oleh dokter yang dilakukan melalui pemeriksaan fisik mencakup pemeriksaan visual, perabaan, penilaian bentuk tubuh, pembengkakan, serta uji fungsi dan sistem saraf.

Namun, pemeriksaan fisik saja tidak cukup untuk memastikan adanya patah tulang, sehingga diperlukan pemeriksaan radiologi, terutama menggunakan foto rontgen (*X-Ray*), sebagai metode utama dalam diagnosis fraktur. Pemeriksaan radiografi digunakan untuk mengevaluasi posisi patah tulang, arah garis fraktur, tingkat pergeseran *fragmen*, serta mengklasifikasikan berbagai jenis fraktur seperti *hairline*, *oblique*, *spiral*, dan *kominutif* [4].

Karena melalui pemeriksaan dokter, sehingga memerlukan ketelitian yang tinggi, pengalaman yang cukup, dan dapat dipengaruhi oleh faktor subjektif. Dalam situasi fraktur halus atau fraktur yang kompleks, interpretasi secara manual berpotensi menyebabkan kesalahan dalam diagnosis. Oleh karena itu, diperlukan sebuah sistem berbasis teknologi yang mampu membantu proses klasifikasi citra *X-Ray* secara otomatis dan lebih akurat. Salah satu metode yang berpotensi memberikan hasil optimal adalah pemanfaatan *Convolutional Neural Network (CNN)* dengan arsitektur VGG16 berbasis *transfer learning* dalam pengenalan pola citra medis. *Transfer learning* pada model memanfaatkan *pretrained weights* dari data set berskala besar sehingga mampu meningkatkan performa klasifikasi, khususnya pada data set medis yang terbatas.


Beberapa penelitian terkait klasifikasi citra *X-Ray* berbasis *deep learning* telah dilakukan sebelumnya. *Deekshith Bolla dan Wisam Bukaita (2025)*, mengusulkan model berbasis *deep learning* untuk deteksi fraktur Multi-region pada area pinggul, lutut, dan tulang belakang dengan performa deteksi yang tinggi [5]. Penelitian lain oleh *Ramadanov et al. (2025)*, menunjukkan bahwa model *deep learning* mampu membantu identifikasi fraktur distal radius pada citra *X-Ray* dengan performa yang sebanding dengan tenaga medis berpengalaman [6]. Selain itu, pendekatan *transfer learning* menggunakan arsitektur VGG16 menunjukkan performa yang baik pada klasifikasi citra medis berbasis *X-Ray*. Penelitian sebelumnya melaporkan bahwa model VGG16 mampu meningkatkan kemampuan ekstraksi fitur dan menghasilkan performa klasifikasi yang tinggi pada citra medis [7]. Penelitian lain menunjukkan bahwa penerapan *transfer learning* berbasis VGG16 mampu meningkatkan generalisasi model dan mempercepat proses pelatihan dibandingkan CNN konvensional [8].

Klasifikasi Multi-kelas fraktur tulang menjadi tantangan karena beberapa jenis fraktur memiliki karakteristik visual yang mirip, seperti *spiral fracture*, *oblique fracture*, dan *impacted fracture*. Selain itu, distribusi data yang tidak seimbang antar kelas dapat memengaruhi performa klasifikasi model. Oleh karena itu, penelitian ini mengimplementasikan metode CNN berbasis *transfer learning* menggunakan arsitektur VGG16 untuk melakukan klasifikasi 11 jenis fraktur tulang dan kondisi normal pada citra *X-Ray*. Model VGG16 digunakan sebagai *feature extractor* dengan proses *fine-tuning* pada beberapa lapisan akhir untuk meningkatkan kemampuan model dalam mengenali pola fraktur secara lebih optimal.

II. METODELOGI PENELITIAN

Penelitian ini bertujuan untuk melakukan klasifikasi Multi-kelas fraktur tulang pada citra *X-Ray* menggunakan metode *transfer learning* berbasis arsitektur VGG16. Model VGG16 digunakan karena memiliki kemampuan ekstraksi fitur yang baik pada citra medis melalui pemanfaatan *pretrained weights* dari data set *ImageNet*. Penelitian ini mengklasifikasikan 11 jenis fraktur tulang dan kondisi normal, yaitu *Avulsion Fracture*, *Comminuted Fracture*, *Fracture Dislocation*, *Greenstick Fracture*, *Hairline Fracture*, *Impacted Fracture*, *Longitudinal Fracture*, *Oblique Fracture*, *Pathological Fracture*, *Spiral Fracture*, dan *Normal*.

Arsitektur VGG16 digunakan sebagai *feature extractor* dengan penambahan beberapa lapisan *fully connected* dan *dropout* untuk meningkatkan performa klasifikasi. Selain itu, proses *fine-tuning* dilakukan pada beberapa lapisan akhir model untuk membantu model mengenali pola fraktur secara lebih optimal pada citra *X-Ray*. Pendekatan *transfer learning* dipilih karena terbukti efektif dalam klasifikasi citra medis, khususnya pada data set dengan jumlah data terbatas. Gambar 1 merepresentasikan *workflow* penelitian klasifikasi fraktur tulang menggunakan metode VGG16 *transfer learning*.



Gambar 1. Diagram workflow penelitian klasifikasi fracture dengan arsitektur VGG16

Metode penelitian ini mengikuti tahapan umum dalam pengembangan sistem yang menggunakan *machine learning* seperti Gambar 1. *Machine Learning (ML)* merupakan cabang dari kecerdasan buatan yang berfokus pada pengembangan algoritma untuk mengidentifikasi pola dalam data secara otomatis. Dalam implementasi praktisnya, *Machine Learning* mengikuti siklus yang mencakup akuisisi data, pra-pemrosesan, pemilihan arsitektur, hingga evaluasi performa guna menghasilkan model yang andal untuk aplikasi dunia nyata [9]. Pada klasifikasi citra medis, proses ini sistem mengekstraksi fitur klinis dari *X-Ray* secara objektif melalui tahapan pelatihan yang terstruktur untuk meminimalkan

kesalahan diagnosis [10]. Setiap langkah dilaksanakan secara berurutan dan teratur untuk menghasilkan model klasifikasi gambar *X-Ray* yang tepat dan dapat diterapkan secara interaktif.

A. Data Collection

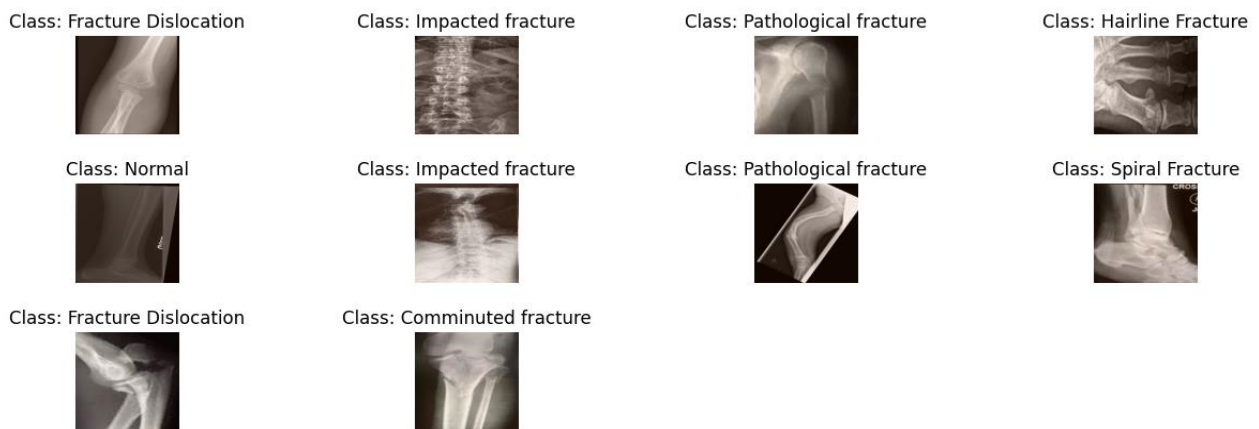
Sebelum melakukan pemrosesan dan membangun model, diperlukan tersedia data set. Untuk penelitian ini menggunakan data set sekunder *image* atau gambar *X-Ray*. Data sekunder merupakan data yang diperoleh peneliti secara tidak langsung dari sumber yang telah tersedia sebelumnya melalui prosedur sistematis, seperti publikasi, laporan, atau database yang relevan. Data tersebut sudah dikumpulkan, diolah, dan disimpan oleh instansi atau lembaga lain[11]. Gambar *X-Ray* merupakan gambar yang didapatkan dari Radiografi *X-Ray* atau alat rentgen. Mekanisme radiografi konvensional mengandalkan atenuasi diferensial dari radiasi Sinar-X saat menembus jaringan tubuh. Perbedaan densitas material menyebabkan tulang yang memiliki kerapatan tinggi menyerap lebih banyak foton sehingga menghasilkan gambaran *radiopaque* (putih), sementara jaringan lunak dengan daya serap rendah tampak lebih *radiolucent* (gelap) [12]. Karakteristik kontras yang tajam inilah yang menjadikan Sinar-X sebagai modalitas utama dalam deteksi fraktur berbasis kecerdasan buatan [13].

Dalam penelitian ini digunakan satu data set citra *X-Ray* yang terdiri dari 11 kelas fraktur tulang dan satu kelas normal. Kelas tersebut meliputi *Avulsion Fracture*, *Comminuted*

Fracture, *Fracture Dislocation*, *Greenstick Fracture*, *Hairline Fracture*, *Impacted Fracture*, *Longitudinal Fracture*, *Oblique Fracture*, *Pathological Fracture*, *Spiral Fracture*, dan *Normal*. Dataset dibagi menjadi data training dan *validation* untuk proses pelatihan dan evaluasi model. Berikut ini jumlah data masing-masing class pada Tabel I. Setiap citra *X-Ray* digunakan sebagai *input* pada model *transfer learning* berbasis VGG16 untuk melakukan klasifikasi multi-kelas fraktur tulang. Distribusi jumlah citra pada masing-masing kelas ditunjukkan pada Gambar 2.

TABEL I
JUMLAH DATA GAMBAR PADA SETIAP KELAS

Nama Kelas	Train	Validasi	Jumlah
Avulsion Fracture	108	11	119
Comminuted Fracture	132	16	148
Fracture Dislocation	149	16	165
Greenstick Fracture	111	9	120
Hairline Fracture	102	9	111
Impacted Fracture	76	8	84
Longitudinal Fracture	76	12	88
Normal	100	10	110
Oblique Fracture	77	10	87
Pathological Fracture	124	19	143
Spiral Fracture	77	5	82
Total Jumlah Data	1132	125	1257



Gambar 2. Contoh dataset dalam pemrosesan VGG16

Berikut ini penjelasan masing-masing kelas untuk Model VGG16 :


- *Avulsion Fracture* (Fraktur Avulsi). Fraktur avulsion terjadi pada saat sebagian kecil tulang tertarik lepas akibat tarikan kuat dari tendon atau ligamen. Pada *X-Ray*, cedera ini tampak sebagai fragmen kecil yang terlepas di dekat sendi. Gejala Fraktur avulsion berupa nyeri dan pembengkakan.



Gambar 3. Avulsion fracture

- *Comminuted Fracture* (Fraktur Kominutif). Fraktur kominutif adalah jenis patah tulang yang ditandai

dengan tulang yang hancur menjadi tiga bagian atau lebih. Kondisi ini diakibatkan oleh benturan keras seperti kecelakaan lalu lintas, jatuh dari ketinggian, atau trauma energi tinggi lainnya. Pada X-Ray tampak pecahan tulang yang tersebar dan tidak beraturan. Pasien Fraktur kominutif mengalami pembengkakan hebat, deformitas ekstremitas, dan nyeri yang intens.




Gambar 4. *Comminuted fracture*

- **Dislocation Fracture** (Fraktur dengan Dislokasi). Fraktur dengan Dislokasi adalah patah tulang yang disertai dengan pergeseran sendi (dislokasi). Selain tulang yang patah, posisi sendi ikut berpindah atau bergeser. Pada visual X-Ray tampak garis patah disertai perubahan posisi sendi yang jelas. *Fracture dislocation* sering terjadi pada bahu, siku, atau pergelangan kaki akibat jatuh keras atau kecelakaan.




Gambar 5. *Dislocation Fracture*

- **Greenstick Fracture** (Fraktur Tulang Hijau). Fraktur greenstick sering terjadi pada anak-anak karena tulang pada anak-anak elastis dan belum tumbuh mengeras. Bentuk area patah mirip seperti ranting hijau yang ditekuk, satu sisi patah sementara sisi lain retak dan tetap utuh. Pada X-Ray tampak garis retakan yang tidak sampai memisahkan tulang sepenuhnya. Gejala Fraktur greenstick berupa nyeri, bengkak ringan, dan ketidakmampuan menahan beban.



Gambar 6. *Greenstick fracture*

- **Hairline Fracture** (Fraktur Rambut). Fraktur hairline adalah patah tulang kecil dan tipis yang sering disebut fraktur stres. Cedera ini muncul akibat penggunaan berulang atau tekanan jangka panjang, bukan trauma besar. Pada visual X-Ray sering tampak samar, sehingga kadang perlu CT scan atau MRI. Gejala Fraktur hairline berupa nyeri bertahap, terutama saat diberi tekanan, dan membaik saat istirahat.



Gambar 7. *Hairline fracture*

- **Impacted Fracture** (Fraktur Impaksi). Fraktur impaksi adalah kondisi pada saat ujung tulang yang patah saling menekan satu sama lain, menyebabkan fragmen tulang tersangkut (*impacted*). Kondisi ini terjadi akibat jatuh vertikal seperti mendarat dengan tangan tegap atau tumit terlebih dahulu. Pada visual X-Ray terlihat fragmen tulang masuk satu sama lain sehingga celah patah tidak terlalu jelas. Namun, posisi patah tampak stabil, cedera ini dapat menimbulkan nyeri hebat dan pembengkakan.




Gambar 8. *Impacted fracture*

- **Longitudinal Fracture** (Fraktur Longitudinal). Fraktur longitudinal adalah patah tulang yang memiliki garis patah sejajar dengan sumbu panjang tulang. Cedera ini disebabkan oleh gaya tekan atau benturan langsung yang membuat tulang retak memanjang. Pada visual X-Ray, tampak jelas retakan lurus memanjang tanpa displaced yang besar. Gejala Fraktur longitudinal berupa nyeri, memar, dan pembengkakan di sepanjang tulang



Gambar 9. *Longitudinal fracture*

- **Normal** (Tidak Ada Fraktur)



Gambar 10. *Normal*

- **Oblique Fracture** (Fraktur Oblik). Kategori Normal menunjukkan bahwa tidak ditemukan tanda fraktur atau kelainan struktural pada citra X-Ray. Tulang tampak utuh tanpa garis patah, tanpa pergeseran, dan tanpa fragmen.

Kondisi normal ini tetap menjadi kelas penting dalam model CNN agar sistem dapat mengenali citra yang sehat secara akurat. Pada kasus klinis, pasien dengan kondisi normal tetap mengalami keluhan seperti nyeri jaringan lunak atau keseleo. Oleh karena itu, klasifikasi Normal menegaskan bahwa struktur tulang tidak mengalami kerusakan. Fraktur oblik ditandai dengan garis patah yang miring pada tulang akibat dari gaya geser atau rotasi kuat. Cedera ini sering terjadi pada kecelakaan olahraga atau jatuh dengan sudut tertentu. Pada *X-Ray* terlihat garis patah diagonal yang memotong tulang. Risiko pergeseran fragmen cukup tinggi karena arah patahan yang tidak stabil. Pasien Fraktur oblik mengalami nyeri signifikan terutama ketika menggerakkan bagian tubuh yang cedera.



Gambar 11. *Oblique fracture*

- *Pathological Fracture* (Fraktur Patologis). Fraktur patologis adalah patah tulang yang terjadi karena kelemahan struktur tulang akibat penyakit, bukan trauma besar. Pada *X-Ray* tampak patah tulang yang tidak proporsional dengan tingkat trauma, dan kadang terlihat lesi atau area menipis pada tulang. Cedera ini dapat terjadi bahkan saat aktivitas ringan seperti bangun dari kursi.



Gambar 12. *Pathological fracture*

- *Spiral Fracture* (Fraktur Spiral). Fraktur spiral terjadi karena putaran atau torsi kuat pada tulang sehingga menghasilkan patahan berbentuk heliks (spiral). Pada *X-Ray* terlihat garis patah melingkar mengikuti bentuk tulang. Cedera ini berisiko tinggi menyebabkan ketidakstabilan dan sering memerlukan tindakan bedah karena fragmen tulang mudah bergeser. Pasien mengalami nyeri intens, deformitas, dan keterbatasan mobilitas.

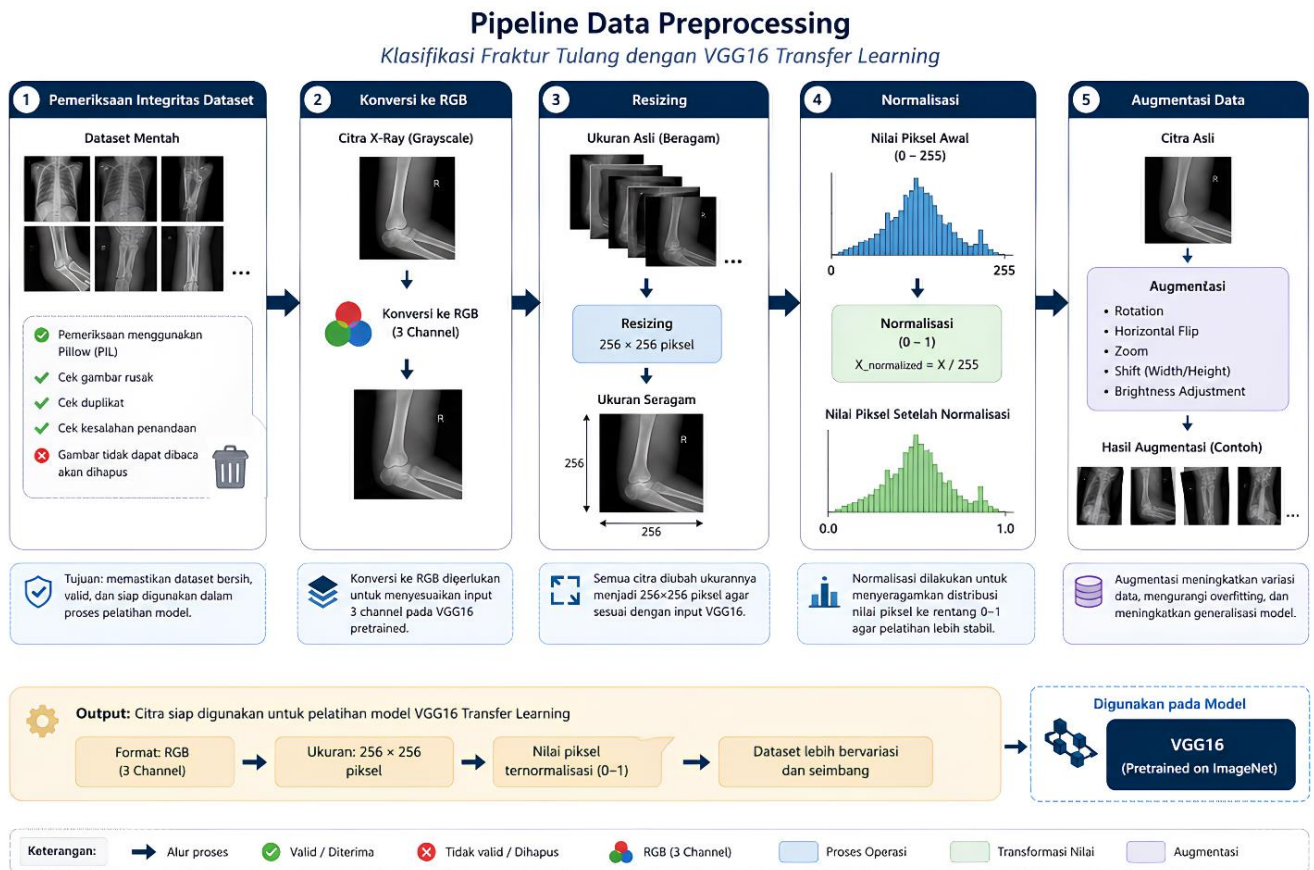


Gambar 13. *Spiral fracture*

B. Data Preprocessing

Data *preprocessing* merupakan tahapan penting dalam pengolahan citra sebelum digunakan dalam model *deep learning*. Proses ini meliputi pembersihan data, perubahan ukuran citra (*resizing*), normalisasi, serta augmentasi data untuk meningkatkan kualitas dan variasi data set. *Preprocessing* bertujuan untuk meningkatkan performa model dalam proses pelatihan serta mengurangi risiko *overfitting* [14], [15]. Tahapan awal dilakukan dengan memeriksa integritas data set untuk memastikan bahwa tidak terdapat gambar yang rusak, duplikat, atau memiliki kesalahan penandaan. Pemeriksaan ini dilakukan menggunakan *Library Pillow (PIL)* untuk memastikan setiap citra dapat diakses dan diproses dengan baik. Gambar yang tidak dapat dibaca akan dihapus dari data set agar tidak memengaruhi proses pelatihan model. Selanjutnya, setiap citra dikonversi ke dalam format RGB dan diubah ukurannya menjadi 256×256 piksel.

Tahap *preprocessing* dilakukan untuk menyesuaikan distribusi nilai piksel citra dengan format *input pretrained* model VGG16 berbasis *ImageNet*. *preprocessing* dilakukan untuk menyesuaikan distribusi nilai piksel citra dengan format *input pretrained* model VGG16 berbasis *ImageNet*. Penyesuaian *preprocessing* pada *transfer learning* diperlukan agar karakteristik citra sesuai dengan kebutuhan model *pretrained*, sehingga proses ekstraksi fitur dapat berjalan lebih optimal pada klasifikasi citra medis [16]. Proses ini dilakukan agar citra input sesuai dengan kebutuhan *model pretrained* sehingga model dapat melakukan ekstraksi fitur secara lebih optimal selama proses pelatihan. Pada penelitian ini, seluruh citra terlebih dahulu dikonversi ke dalam format RGB dan diubah ukurannya menjadi 256×256 piksel sebelum dilakukan *preprocessing*. Namun, citra *X-Ray* pada dasarnya berupa *grayscale*, konversi ke format RGB diperlukan untuk menyesuaikan *input* tiga channel pada arsitektur *pretrained* VGG16 [17]. Selain itu, penggunaan *preprocessing* khusus pada *transfer learning* terbukti mampu meningkatkan stabilitas pelatihan, mempercepat konvergensi model, serta meningkatkan kemampuan generalisasi model pada klasifikasi citra medis [18].



Gambar 14. Tahap Pra-Pemrosesan Data

C. Modeling

Tahapan modeling merupakan proses perancangan dan pembangunan model *deep learning* yang digunakan untuk melakukan klasifikasi Multi-kelas fraktur tulang pada citra X-Ray. Pada penelitian ini digunakan metode transfer learning berbasis arsitektur VGG16. VGG16 merupakan salah satu arsitektur *Convolutional Neural Network (CNN)* yang banyak digunakan pada klasifikasi citra medis berbasis *transfer learning* karena memiliki kemampuan ekstraksi fitur yang baik pada berbagai tugas klasifikasi citra [19]. Arsitektur ini banyak digunakan pada berbagai penelitian klasifikasi citra, termasuk *medical imaging*.

Transfer learning model memanfaatkan *pretrained weights* sehingga proses ekstraksi fitur dapat dilakukan secara lebih optimal, khususnya pada data set medis dengan jumlah data terbatas [19]. Dalam penelitian ini, model VGG16 digunakan sebagai *feature extractor* dengan penambahan beberapa lapisan *fully connected*, *batch normalization*, dan *dropout* untuk meningkatkan performa klasifikasi. Selain itu, dilakukan proses *fine-tuning* pada beberapa lapisan akhir VGG16 untuk membantu model mengenali pola fraktur secara lebih spesifik pada citra X-Ray. Pada Gambar 15 menunjukkan arsitektur VGG16 *transfer learning* yang digunakan dalam penelitian ini. Citra X-Ray berukuran

256×256×3 digunakan sebagai input model. Bagian utama arsitektur terdiri dari 5 *convolutional block* VGG16 yang berperan sebagai *feature extractor*. Setiap block terdiri dari beberapa lapisan konvolusi dengan aktivasi *ReLU* dan diikuti oleh *max pooling* untuk mereduksi dimensi *feature map*. *Output* dari block terakhir VGG16 menghasilkan *feature map* berukuran 8×8×512. *Feature map* tersebut kemudian diproses menggunakan *GlobalAveragePooling2D* untuk menghasilkan vektor fitur berdimensi 512. Selanjutnya, vektor fitur diteruskan ke lapisan *Dense* dengan 128 neuron, *BatchNormalization*, dan *dropout*. Lapisan tambahan ini digunakan untuk menyesuaikan *fitur pretrained* VGG16 dengan karakteristik citra X-Ray fraktur tulang serta mengurangi risiko *overfitting*. Pada bagian akhir, digunakan lapisan *Dense* dengan 11 neuron dan fungsi aktivasi *Softmax* untuk menghasilkan probabilitas klasifikasi pada 11 kelas, yaitu *Avulsion Fracture*, *Comminuted Fracture*, *Fracture Dislocation*, *Greenstick Fracture*, *Hairline Fracture*, *Impacted Fracture*, *Longitudinal Fracture*, *Normal*, *Oblique Fracture*, *Pathological Fracture*, dan *Spiral Fracture*.

Berdasarkan Tabel II, *feature map* akhir dari block ke-5 memiliki ukuran 8×8×512. Jika menggunakan *Flatten* secara langsung, *feature map* tersebut akan menghasilkan 32.768 fitur. Namun, pada penelitian ini digunakan

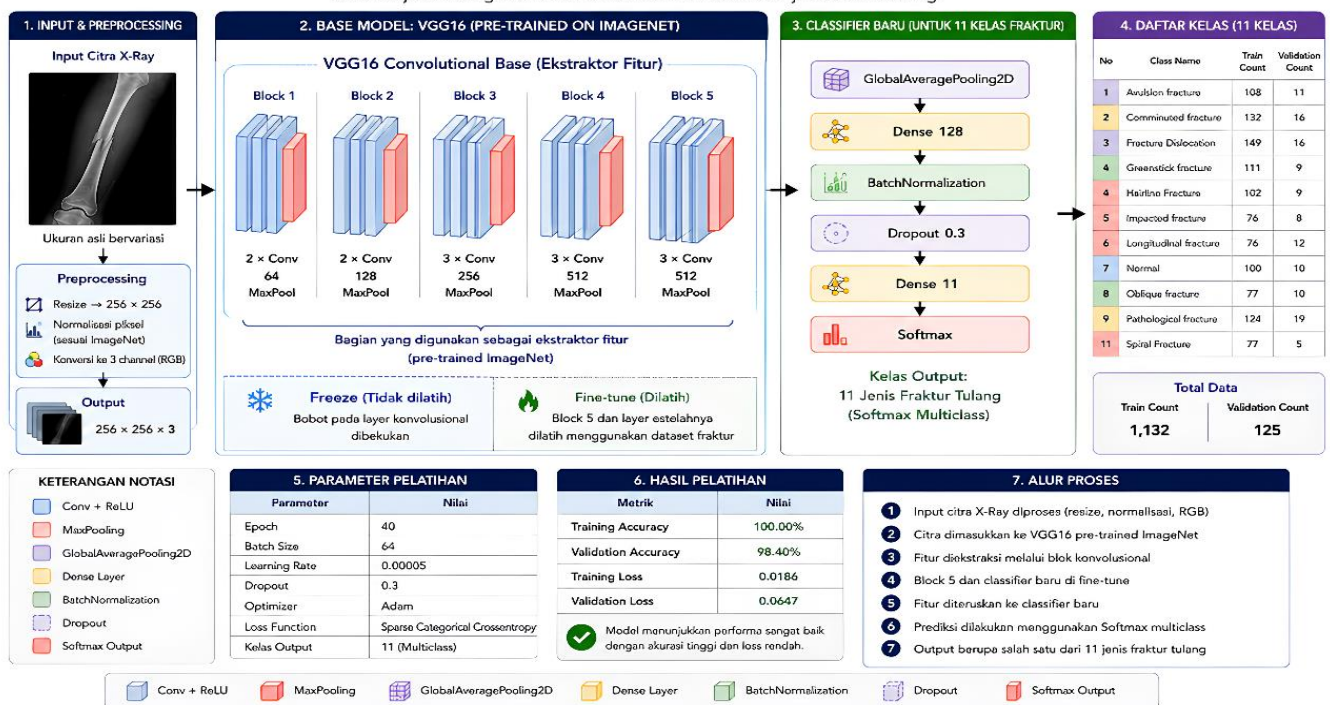
GlobalAveragePooling2D untuk mereduksi *feature map* $8 \times 8 \times 512$ menjadi vektor fitur berdimensi 512. Penggunaan *GlobalAveragePooling2D* bertujuan untuk mengurangi jumlah parameter dan kompleksitas komputasi sebelum masuk ke *fully connected layer*. Vektor fitur berdimensi 512 kemudian diteruskan ke lapisan Dense dengan 128 neuron dan fungsi aktivasi *ReLU*. Setelah itu, *BatchNormalization* diterapkan untuk membantu menstabilkan distribusi aktivasi selama proses pelatihan, sedangkan *Dropout* digunakan untuk mengurangi risiko *overfitting* dengan menonaktifkan sebagian neuron secara acak. Pada lapisan akhir, digunakan *Dense layer* dengan 11 neuron dan fungsi aktivasi *Softmax* untuk menghasilkan probabilitas klasifikasi pada setiap kelas, yaitu *Avulsion Fracture*, *Comminuted Fracture*, *Fracture Dislocation*, *Greenstick Fracture*, *Hairline Fracture*, *Impacted Fracture*, *Longitudinal Fracture*, *Normal*, *Oblique Fracture*, *Pathological Fracture*, dan *Spiral Fracture*. Lapisan *Conv2D* disini berfungsi sebagai ekstraktor fitur utama yang mendeteksi pola visual penting pada citra, termasuk bentuk fraktur yang kompleks seperti garis patahan tipis, fraktur spiral, maupun fragmen kecil. Lapisan konvolusi pada arsitektur VGG16 berfungsi sebagai ekstraktor fitur utama yang mampu mengenali pola visual penting pada citra *X-Ray*, seperti tekstur tulang, garis fraktur, dan struktur radiografi [20].

TABEL I
ARSITEKTUR VGG16

Tahap	Output Shape	Keterangan
Input	256×256×3	Citra X-Ray RGB sebagai input model.
Block 1 + MaxPooling	128×128×64	Ekstraksi fitur dasar.
Block 2 + MaxPooling	64×64×128	Ekstraksi fitur menengah.
Block 3 + MaxPooling	32×32×256	Ekstraksi fitur kompleks.
Block 4 + MaxPooling	16×16×512	Ekstraksi fitur radiografi.
Block 5 + MaxPooling	8×8×512	Ekstraksi pola fraktur.
GlobalAveragePooling2D	512	Reduksi feature map
Dense	128	Representasi fitur.
Output Softmax	11	Probabilitas klasifikasi.

ARSITEKTUR VGG16 TRANSFER LEARNING UNTUK KLASIFIKASI FRAKTUR TULANG (11 KELAS)

Pre-trained VGG16 (ImageNet) digunakan sebagai ekstraktor fitur, kemudian fine-tuning pada lapisan tertentu dan dilanjutkan dengan classifier baru untuk mendeteksi 11 jenis fraktur tulang.



Gambar 15. Layer model VGG16 yang di implementasikan

Penelitian *Guerhazi et al. (2022)* menunjukkan bahwa penggunaan *convolutional layer* dan *pooling layer* pada CNN efektif dalam meningkatkan kemampuan ekstraksi fitur pada klasifikasi citra medis serta membantu mengurangi

kompleksitas komputasi selama proses pelatihan [4]. Sementara itu, penggunaan *pooling layer* bertujuan untuk mereduksi dimensi fitur dengan tetap mempertahankan informasi penting, sehingga menurunkan kompleksitas komputasi [4].

Hal ini diperkuat oleh *Purwono et al. (2022)*, yang menyatakan bahwa lapisan *pooling* membantu model menjadi lebih efisien dan tahan terhadap pergeseran kecil pada citra sekaligus mencegah *overfitting* dengan menyaring fitur yang redundan [21]. Pada model ini, telah diterapkan lapisan *dropout*, yang bekerja dengan menonaktifkan neuron secara acak selama proses pelatihan. Teknik ini efektif meningkatkan kemampuan generalisasi jaringan saraf karena mencegah neuron bergantung satu sama lain secara berlebihan dan membantu mengurangi risiko *overfitting* pada data latih, sebagaimana dibahas dalam literatur terkini tentang pendekatan regulasi *dropout* dalam CNN (*Salehin & Kang, 2023*) [22]. Operasi konvolusi, fungsi aktivasi, dan fungsi loss pada arsitektur VGG16 mengikuti prinsip umum *Convolutional Neural Network (CNN)* dalam proses ekstraksi fitur dan klasifikasi citra medis. Formulasi matematis operasi konvolusi, fungsi aktivasi *ReLU*, fungsi *Softmax*, dan *categorical crossentropy* ditunjukkan pada Persamaan (1) sampai Persamaan (4) [23].

- Operasi Konvolusi

$$Y(i, j) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} X(i + m, j + n) \cdot W(m, n) \quad (1)$$

Keterangan:

$X(i, j)$: nilai piksel citra input pada posisi (i, j)

$W(m, n)$: beban kernel / filter

$Y(i, j)$: hasil feature map

$M \times N$: ukuran kernel (misalnya 3×3)

- Fungsi Aktivasi *ReLU*

$$f(x) = \max(0, x) \quad (2)$$

- Fungsi *Softmax* (Lapisan Output)

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3)$$

Keterangan:

z_i : skor dari neuron ke- i

K : jumlah kelas

$P(y_i)$: probabilitas prediksi untuk kelas ke- i .

- Loss Function

$$L = - \sum_{i=1}^K y_i \log(\hat{y}_i) \quad (4)$$

Keterangan:

y_i : label sebenarnya

\hat{y}_i : probabilitas prediksi

Semakin kecil nilai loss maka performa model semakin baik. Fungsi ini digunakan untuk mengukur seberapa besar perbedaan antara hasil prediksi \hat{y}_i dan label sebenarnya y_i . Semakin kecil nilai *loss*, semakin baik performa model.

D. Training dan Evaluation

Tahap *training* dan *evaluation* dilakukan untuk melatih model *VGG16 transfer learning* dalam mengenali pola visual pada citra *X-Ray* fraktur tulang serta mengevaluasi performa klasifikasi model. Proses pelatihan dilakukan menggunakan *framework TensorFlow* dan *Keras*. Dataset yang digunakan merupakan data hasil preprocessing dan augmentasi yang telah disesuaikan dengan kebutuhan *input pretrained VGG16*. Pada penelitian ini digunakan *Optimizer Adam* karena mampu melakukan pembaruan bobot secara adaptif sehingga proses konvergensi model dapat berlangsung lebih stabil dan efisien [24]. Fungsi *loss* yang digunakan adalah *sparse categorical crossentropy* karena penelitian ini melakukan klasifikasi Multi-kelas terhadap 11 kelas fraktur tulang dan kelas normal. Proses pelatihan dilakukan selama 40 *epoch* dengan *batch size* sebesar 64 dan menggunakan data validation sebesar 10% dari total dataset pelatihan. Selain itu, diterapkan *callback EarlyStopping* untuk menghentikan proses *training* secara otomatis apabila performa validasi tidak mengalami peningkatan dalam beberapa *epoch* berturut-turut. Strategi ini digunakan untuk membantu mengurangi risiko *overfitting* selama proses pelatihan model [25].

Selain *EarlyStopping*, dilakukan proses *fine-tuning* pada beberapa lapisan akhir VGG16, khususnya pada *block5*, untuk meningkatkan kemampuan model dalam mengenali karakteristik pola fraktur tulang secara lebih spesifik. Proses *fine-tuning* dilakukan menggunakan *learning rate* yang lebih kecil agar pembaruan bobot pretrained tetap stabil selama proses pelatihan. Evaluasi performa model dilakukan menggunakan beberapa metrik, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu, digunakan *confusion matrix* untuk melihat distribusi hasil prediksi model pada masing-masing kelas fraktur tulang [26]. Hasil pelatihan menunjukkan bahwa model mengalami proses konvergensi yang stabil. Nilai *training accuracy* dan *validation accuracy* meningkat secara bertahap hingga mencapai performa optimal dengan selisih yang tidak terlalu jauh. Selain itu, nilai *training loss* dan *validation loss* mengalami penurunan secara konsisten selama proses pelatihan. Hal ini menunjukkan bahwa model mampu melakukan generalisasi dengan baik tanpa mengalami *overfitting* yang signifikan. Grafik *training accuracy* dan *validation accuracy* menunjukkan pola peningkatan yang stabil pada setiap *epoch*, sedangkan grafik *training loss* dan *validation loss* menunjukkan penurunan yang konsisten hingga mendekati titik konvergensi. Stabilitas kurva pelatihan menunjukkan bahwa penerapan *preprocessing*, *data augmentation*, *BatchNormalization*, *Dropout*, dan *fine-tuning* membantu meningkatkan performa model dalam klasifikasi citra *X-Ray* fraktur tulang.

Setelah proses pelatihan selesai, model dievaluasi menggunakan *validation set* untuk mengukur performa klasifikasi pada data yang tidak digunakan secara langsung selama proses pelatihan. Evaluasi dilakukan dengan menghitung metrik-metrik pada rumus (5) sampai rumus (8).

- Akurasi (*accuracy*). Akurasi menunjukkan persentase jumlah prediksi yang benar terhadap total prediksi, dimana True Positive (TP) : Jumlah data positif yang berhasil diprediksi benar sebagai positif oleh model, True Negative (TN): Jumlah data negatif yang berhasil diprediksi benar sebagai negatif oleh model, False Positive (FP): Jumlah data negatif, namun diprediksi salah sebagai positif oleh model, False Negative (FN): Jumlah data positif, namun diprediksi salah sebagai negatif oleh model.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

- Presisi (*Precision*). Kemampuan model dalam menghindari kesalahan klasifikasi positif palsu.

$$Precision = \frac{TP}{TP+FP} \quad (6)$$

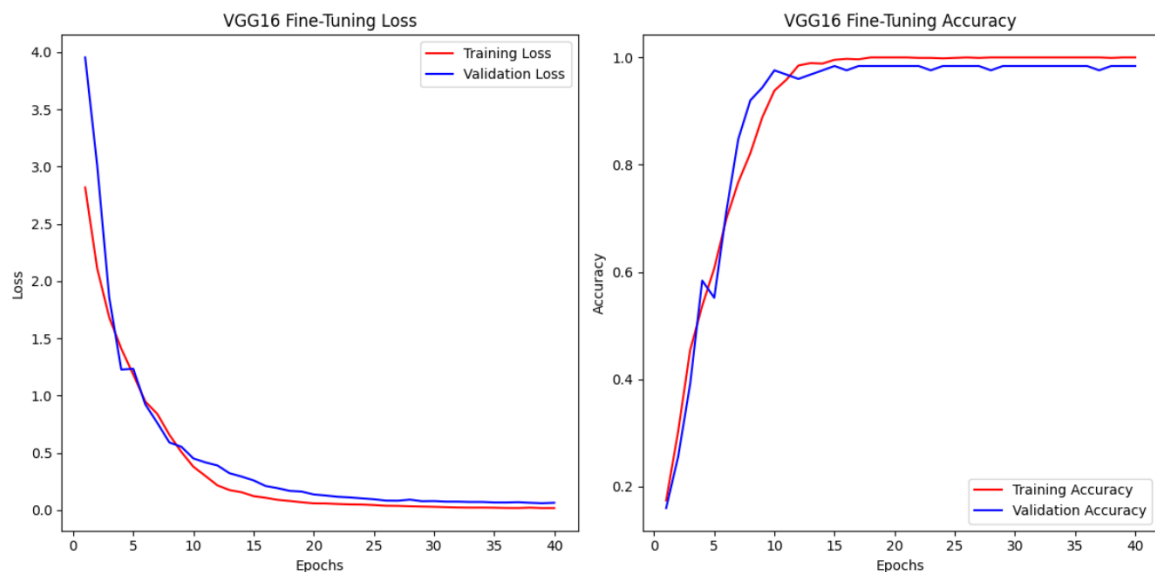
- Recall (*Sensitivity*). Kemampuan model dalam mengenali seluruh data positif yang benar.

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

- *F1-Score*. Rata-rata harmonik antara presisi dan *recall*, digunakan sebagai ukuran keseimbangan performa model.

$$F1 = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (8)$$

Gambar 17 merupakan evaluasi terbaru berdasarkan pelatihan Model VGG16 dengan *Transfer Learning*. Hasil evaluasi model VGG16 *transfer learning* menunjukkan performa klasifikasi yang sangat baik pada data set citra X-Ray fraktur tulang. Model berhasil memperoleh nilai *accuracy* sebesar 98,40%, *precision macro* sebesar 97,95%, dan *recall macro* sebesar 97,95%. Nilai tersebut menunjukkan bahwa model mampu melakukan klasifikasi Multi-kelas secara akurat dan konsisten pada sebagian besar kelas fraktur tulang. Berdasarkan *classification report*, sebagian besar kelas memperoleh nilai *precision*, *recall*, dan *F1-score* mendekati 1,00% . Kelas seperti *Avulsion Fracture*, *Comminuted Fracture*, *Fracture Dislocation*, *Hairline Fracture*, *Longitudinal Fracture*, *Normal*, *Pathological Fracture*, dan *Spiral Fracture* berhasil diklasifikasikan dengan sangat baik tanpa kesalahan prediksi yang signifikan.



Gambar 16. Grafik training dan validation model VGG16

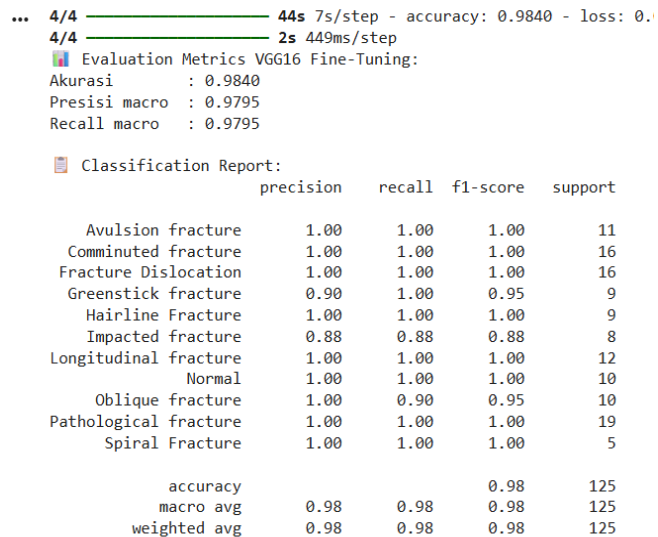
Beberapa kelas yang mengalami sedikit kesalahan klasifikasi, seperti *Greenstick Fracture*, *Impacted Fracture*, dan *Oblique Fracture*. Pada kelas *Impacted Fracture* diperoleh nilai *precision*, *recall*, dan *F1-score* sebesar 0,88. Hal ini menunjukkan bahwa beberapa citra pada kelas tersebut memiliki karakteristik visual yang mirip dengan kelas fraktur lainnya sehingga lebih sulit dibedakan oleh

model. Berdasarkan *confusion matrix*, kesalahan klasifikasi yang terjadi berada dalam jumlah yang relatif kecil sehingga tidak memberikan pengaruh signifikan terhadap performa keseluruhan model. Secara keseluruhan, hasil evaluasi menunjukkan bahwa penerapan VGG16 *transfer learning* dengan *fine-tuning*, *BatchNormalization*, *Dropout*, serta preprocessing dan augmentasi data mampu meningkatkan

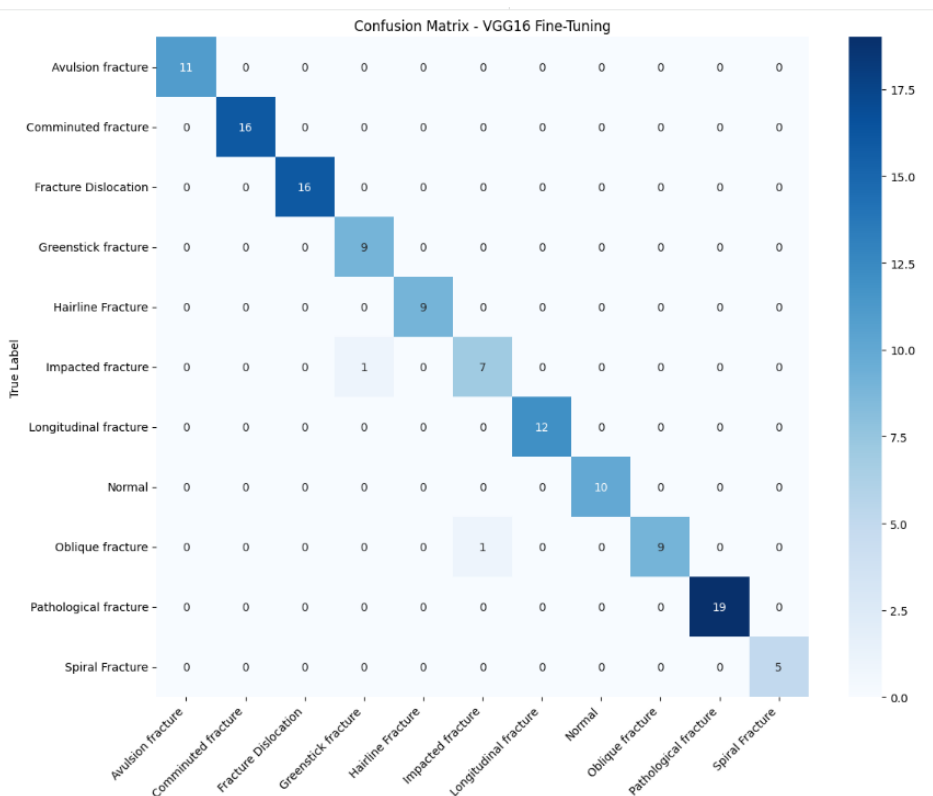
kemampuan generalisasi model dalam melakukan klasifikasi citra X-Ray fraktur tulang secara Multi-kelas dengan performa yang sangat tinggi. Stabilitas nilai *accuracy* dan *loss* selama proses pelatihan menunjukkan bahwa model tidak mengalami *overfitting* yang signifikan.

Berdasarkan *confusion matrix* pada Gambar 18, sebagian besar prediksi model berada pada diagonal utama yang menunjukkan bahwa model mampu melakukan klasifikasi citra X-Ray fraktur tulang dengan sangat baik. Hampir seluruh kelas berhasil diprediksi secara tepat tanpa kesalahan klasifikasi yang signifikan. Kelas *Avulsion Fracture*, *Comminuted Fracture*, *Fracture Dislocation*, *Hairline Fracture*, *Longitudinal Fracture*, *Normal*, *Pathological Fracture*, dan *Spiral Fracture* menunjukkan hasil prediksi sempurna, pada seluruh data pada kelas tersebut berhasil diklasifikasikan dengan benar oleh model. Dengan demikian, ada sedikit kesalahan klasifikasi pada beberapa kelas tertentu. Pada kelas *Impacted Fracture* ada 1 data yang diprediksi sebagai *Greenstick Fracture*, sedangkan pada kelas *Oblique Fracture* terdapat 1 data yang diprediksi sebagai *Impacted Fracture*. Kesalahan klasifikasi tersebut diduga disebabkan oleh kemiripan pola visual dan karakteristik garis fraktur antar kelas pada citra X-Ray sehingga model mengalami kesulitan dalam membedakan beberapa fitur tertentu. Secara keseluruhan, jumlah misklasifikasi yang terjadi sangat kecil

dibandingkan jumlah prediksi benar pada setiap kelas. Hasil *confusion matrix* ini menunjukkan bahwa model VGG16 transfer learning memiliki kemampuan generalisasi yang sangat baik dalam melakukan klasifikasi Multi-kelas fraktur tulang dengan tingkat akurasi yang tinggi.



Gambar 17. Evaluasi model VGG16



Gambar 18. Confusion Matrix model VGG16

III. HASIL DAN PEMBAHASAN

Hasil penelitian menunjukkan bahwa metode VGG16 *transfer learning* mampu memberikan performa klasifikasi yang sangat tinggi pada citra X-Ray fraktur tulang. Tingginya nilai *accuracy*, *precision*, *recall*, dan *F1-score* menunjukkan bahwa model mampu mengenali pola visual fraktur secara efektif pada sebagian besar kelas. Performa model yang tinggi dipengaruhi oleh penggunaan *pretrained model VGG16* berbasis *ImageNet* yang mampu melakukan ekstraksi fitur secara lebih optimal dibandingkan CNN konvensional. Selain itu, proses *fine-tuning* pada beberapa lapisan akhir membantu model menyesuaikan representasi fitur terhadap karakteristik citra X-Ray fraktur tulang. Penerapan *preprocessing*, *data augmentation*, *BatchNormalization*, dan *Dropout* membantu meningkatkan kemampuan generalisasi model sehingga proses pelatihan dapat berlangsung stabil tanpa mengalami *overfitting* yang signifikan.

Tabel III menunjukkan hasil akhir proses training model VGG16 *transfer learning* setelah dilakukan pelatihan selama 40 *epoch*. Model berhasil memperoleh *training accuracy* sebesar 100,00% dan *validation accuracy* sebesar 98,40%, yang menunjukkan bahwa model mampu mempelajari pola visual citra X-Ray fraktur tulang dengan sangat baik pada data pelatihan maupun data validasi. Selain itu, diperoleh nilai *training loss* sebesar 0,0186 dan *validation loss* sebesar 0,0647. Nilai *loss* yang rendah menunjukkan bahwa kesalahan prediksi model semakin kecil selama proses pelatihan. Selisih antara *training accuracy* dan *validation accuracy* yang relatif kecil menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* yang signifikan. Stabilitas performa model selama proses pelatihan dipengaruhi oleh penerapan *preprocessing*, *data augmentation*, *BatchNormalization*, *Dropout*, serta *fine-tuning* pada beberapa lapisan akhir VGG16. Kombinasi teknik tersebut membantu model dalam mengekstraksi fitur citra secara lebih optimal sehingga mampu meningkatkan performa klasifikasi Multi-kelas fraktur tulang pada citra X-Ray.

TABEL II
TRAINING MODEL VGG16 EPOCH 40

Training	Nilai
Epoch	40
Batch Size	64
Learning Rate	0.00005
Akurasi Pelatihan	100.00%
Akurasi Validasi	98.40%
Loss Validasi	0.0647

Berdasarkan hasil evaluasi pada Tabel VI, model VGG16 *transfer learning* memperoleh performa klasifikasi yang sangat baik pada dataset citra X-Ray fraktur tulang. Model berhasil mencapai nilai akurasi sebesar 98,40%, *precision macro* sebesar 97,95%, dan *recall macro* sebesar 97,95%. Nilai tersebut menunjukkan bahwa model mampu melakukan klasifikasi Multi-kelas secara akurat dan konsisten pada sebagian besar kelas fraktur tulang.

TABEL III
EVALUASI MODEL VGG16

Metrik Evaluasi (Validation Set)	Nilai
Akurasi	0.9840
Presisi (macro)	0.9795
Recall (macro)	0.9795
Jumlah Data	1257

Pada Tabel IV tingginya nilai *precision* menunjukkan bahwa sebagian besar hasil prediksi model sesuai dengan label sebenarnya, sedangkan nilai *recall* yang tinggi menunjukkan bahwa model mampu mengenali hampir seluruh data pada masing-masing kelas dengan baik. Selain itu, keseimbangan antara *precision* dan *recall* menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dalam membedakan berbagai jenis fraktur tulang pada citra X-Ray. Performa model yang tinggi dipengaruhi oleh penerapan *transfer learning* menggunakan arsitektur VGG16 yang mampu melakukan ekstraksi fitur secara lebih optimal dibandingkan CNN konvensional. Selain itu, penerapan *preprocessing*, *data augmentation*, *BatchNormalization*, *Dropout*, dan *fine-tuning* pada beberapa lapisan akhir VGG16 membantu meningkatkan stabilitas proses pelatihan dan mengurangi risiko *overfitting*. Namun memperoleh hasil evaluasi yang sangat tinggi, beberapa kesalahan klasifikasi pada kelas tertentu yang memiliki karakteristik visual serupa. Namun secara keseluruhan, model mampu menunjukkan performa yang stabil dan efektif dalam melakukan klasifikasi Multi-kelas fraktur tulang berbasis citra X-Ray.

TABEL V
HASIL MASING-MASING KELAS MODEL VGG16

Nama Kelas	Jumlah Data	Prediksi		Akurasi (%)
		Benar	Salah	
Avulsion Fracture	11	11	0	100
Comminuted Fracture	16	16	0	100
Fracture Dislocation	16	16	0	100
Greenstick Fracture	9	8	1	88
Hairline Fracture	9	9	0	100
Impacted Fracture	8	7	1	87.5
Longitudinal Fracture	12	12	0	100
Normal	10	10	0	100
Oblique Fracture	10	9	1	90
Pathological Fracture	19	19	0	100
Spiral Fracture	5	5	0	100.00
Rata-rata akurasi				96.94

Perhitungan *accuracy* pada masing-masing kelas dilakukan dengan membandingkan jumlah prediksi benar terhadap total data pada setiap kelas. Rumus *accuracy* per kelas dan semua kelas ditunjukkan pada persamaan (9) dan (11).

- Accuracy per kelas. Perhitungan *accuracy* pada masing-masing kelas dilakukan dengan membandingkan jumlah prediksi benar terhadap total data pada setiap kelas. Rumus *accuracy* per kelas ditunjukkan pada persamaan (9)

$$Accuracy_{class} = \frac{Jumlah\ Prediksi\ Benar}{Jumlah\ Data} \times 100\% \quad (9)$$

Contoh Impact Fracture:

$$Accuracy = \frac{7}{8} \times 100\% = 87.50\% \quad (10)$$

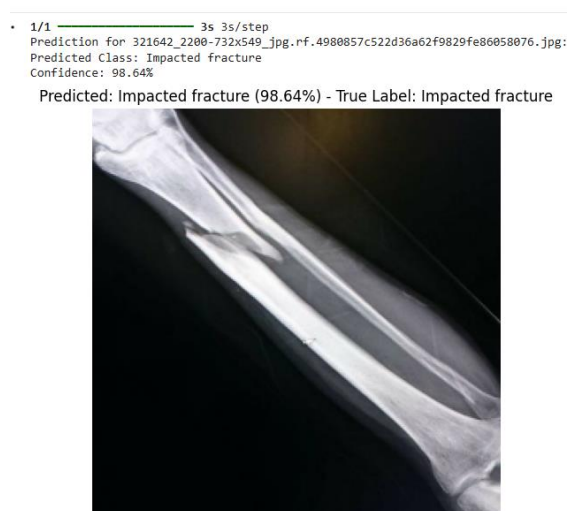
- Average accuracy semua kelas. Kemampuan model dalam mengenali seluruh data positif yang benar.

$$Average\ Accuracy = \frac{\sum Accuracy_{class}}{Jumlah\ Kelas} \quad (11)$$

Perhitungan Manual:

$$Average\ Accuracy = \frac{1066.39}{11} = 96.94\% \quad (12)$$

Berdasarkan hasil evaluasi masing-masing kelas pada Tabel V, sebagian besar kelas fraktur tulang berhasil diklasifikasikan dengan sangat baik oleh model VGG16 transfer learning. Beberapa kelas seperti *Avulsion Fracture*, *Comminuted Fracture*, *Fracture Dislocation*, *Hairline Fracture*, *Longitudinal Fracture*, *Normal*, *Pathological Fracture*, dan *Spiral Fracture* memperoleh *accuracy* sebesar 100%, yang menunjukkan bahwa seluruh data pada kelas tersebut berhasil diprediksi dengan benar oleh model. Namun, terdapat beberapa kelas yang mengalami sedikit kesalahan klasifikasi, seperti *Greenstick Fracture* dengan *accuracy* 88,89%, *Impacted Fracture* dengan *accuracy* 87,50%, dan *Oblique Fracture* dengan *accuracy* 90,00%. Kesalahan klasifikasi tersebut disebabkan oleh kemiripan pola visual antar jenis fraktur sehingga model mengalami kesulitan dalam membedakan karakteristik tertentu pada citra *X-Ray*. Secara keseluruhan, rata-rata akurasi seluruh kelas mencapai 96,94%, yang menunjukkan bahwa model memiliki performa klasifikasi Multi-kelas yang sangat baik dan mampu mengenali berbagai jenis fraktur tulang secara konsisten. Tingginya rata-rata akurasi per kelas menunjukkan bahwa penerapan transfer learning berbasis VGG16 mampu meningkatkan kemampuan ekstraksi fitur dan generalisasi model pada klasifikasi citra medis berbasis *X-Ray*. Selain dilakukan evaluasi menggunakan metrik klasifikasi dan *confusion matrix*, dalam penelitian ini melakukan pengujian langsung terhadap citra *X-Ray* untuk melihat kemampuan model dalam melakukan prediksi secara nyata. Contoh hasil prediksi model VGG16 *transfer learning* terhadap citra *X-Ray* fraktur tulang ditunjukkan pada Gambar 19.



Gambar 19. Test model VGG16

Gambar 19 menunjukkan contoh hasil prediksi model terhadap citra *X-Ray* fraktur tulang. Model berhasil mengklasifikasikan citra sebagai *Impacted Fracture* dengan *confidence* sebesar 98,64%. Hasil tersebut menunjukkan bahwa model mampu mengenali pola visual fraktur dengan baik berdasarkan fitur yang diekstraksi dari citra *X-Ray*. Tingginya nilai *confidence* menunjukkan bahwa model memiliki tingkat keyakinan yang tinggi terhadap hasil prediksi yang diberikan. Kemampuan ini dipengaruhi oleh penerapan transfer learning berbasis VGG16 yang mampu melakukan ekstraksi fitur secara efektif pada citra medis. Selain itu, preprocessing, augmentasi data, dan *fine-tuning* membantu meningkatkan kemampuan generalisasi model terhadap berbagai jenis fraktur tulang.

IV. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, metode *transfer learning* menggunakan arsitektur VGG16 berhasil diimplementasikan untuk klasifikasi Multi-kelas fraktur tulang berbasis citra *X-Ray*. Tahap preprocessing seperti *resizing citra*, preprocessing VGG16, dan *augmentasi data* mampu membantu meningkatkan kualitas data masukan sehingga proses pelatihan model dapat berjalan secara lebih optimal. Model VGG16 *transfer learning* yang dibangun menggunakan *pretrained ImageNet*, *BatchNormalization*, *Dropout*, dan *fine-tuning* pada beberapa lapisan akhir menunjukkan performa klasifikasi yang sangat baik. Hasil evaluasi model memperoleh *accuracy* 98,40%, *precision macro* 97,95%, dan *recall macro* 97,95%. Selain itu, sebagian besar kelas fraktur berhasil diklasifikasikan dengan tingkat akurasi yang sangat tinggi. Hasil penelitian menunjukkan bahwa *transfer learning* berbasis VGG16 mampu melakukan ekstraksi fitur citra *X-Ray* secara efektif sehingga mampu mengenali pola fraktur tulang dengan baik. Dengan demikian, terdapat beberapa kesalahan klasifikasi pada kelas tertentu yang memiliki karakteristik visual serupa, seperti *Impacted Fracture* dan *Oblique Fracture*. Untuk penelitian selanjutnya,

disarankan melakukan penambahan jumlah dataset, penyeimbangan distribusi data antar kelas, serta pengujian menggunakan arsitektur *deep learning* lainnya seperti *EfficientNet* atau *DenseNet* untuk memperoleh performa klasifikasi yang lebih optimal.

DAFTAR PUSTAKA

- [1] Badan Pusat Statistik (BPS), *Statistik T Ransportasi Darat Land Transportation Statistics 2024*, vol. 10. Badan Pusat Statistik, 2025. Accessed: Apr. 02, 2026. [Online]. Available: <https://www.bps.go.id/publication/2025/12/01/ed7ff73d58fc0719ee3df145/statistik-transportasi-darat-2024.html>
- [2] J. Kesehatan Qamarul Huda *et al.*, "Usia Dan Lokasi Fraktur Berhubungan Dengan Lama Rawat Pasca Bedah Open Reduction And Internal Fixation (ORIF) Ekstremitas Bawah," vol. 13, no. 2, pp. 1–8, 2025, doi: 10.37824/jkqh.v13i1.2025.
- [3] E. Suara, D. Retnaningsih, and E. P. Sugianto, "The Influence Of Pre-Operative Care On Pre-Operative Anxiety Of Fracture Patients," p. 1724, 2025, doi: <http://jurnal.globalhealthsciencegroup.com/index.php/JLH>.
- [4] A. Guermazi *et al.*, "Improving Radiographic Fracture Recognition Performance and Efficiency Using Artificial Intelligence," *Radiology*, vol. 302, no. 3, pp. 627–636, Mar. 2022, doi: 10.1148/radiol.210937.
- [5] D. Bolla and W. Bukaita, "Multi-Region Bone Fracture Detection in X-Ray Images using Deep Learning," *Med. Res. Arch.*, vol. 13, no. 12, 2025, doi: 10.18103/mra.v13i12.7099.
- [6] N. Ramadanov *et al.*, "Artificial intelligence-guided distal radius fracture detection on plain radiographs in comparison with human raters," *J. Orthop. Surg. Res.*, vol. 20, no. 1, Dec. 2025, doi: 10.1186/s13018-025-05888-9.
- [7] R. Adhyaksa and B. Purnama, "Application of VGG16 in Automated Detection of Bone Fractures in X-Ray Images," *Jurnal RESTI*, vol. 9, no. 1, pp. 118–129, 2025, doi: 10.29207/RESTI.V9I1.6101.
- [8] S. Gupta, D. Sharma, D. Ahilya, and V. Vidyalaya, "Bone Fracture Classification Using Transfer Learning".
- [9] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," *SN Comput. Sci.*, vol. 2, no. 3, May 2021, doi: 10.1007/S42979-021-00592-X.
- [10] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning," *Electronic Markets 2021 31:3*, vol. 31, no. 3, pp. 685–695, Apr. 2021, doi: 10.1007/S12525-021-00475-2.
- [11] Prof. Dr. Sugiyono, *Metode Penelitian Kuantitatif*. 2023.
- [12] M. E. B. M. Mustafa A. Mafraji, "Computed Tomography (CT) - Special Subjects - MSD Manual Professional Edition." Accessed: Apr. 05, 2026. [Online]. Available: <https://www.msmanuals.com/professional/special-subjects/principles-of-radiologic-imaging/computed-tomography-ct>
- [13] A. Elkohail *et al.*, "Artificial Intelligence in Bone Fracture Detection: A Review of Evidence, Limitations, and Clinical Integration," *Cureus*, Nov. 2025, doi: 10.7759/cureus.97674.
- [14] M. A. Al-Fahrezi, "Pengaruh Augmentasi Data Terhadap Akurasi Pelatihan Model CNN untuk Klasifikasi Jenis Ikan," *JITSI : Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 6, no. 2, pp. 177–185, Jun. 2025, doi: 10.62527/JITSI.6.2.471.
- [15] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *Journal of Big Data 2019 6:1*, vol. 6, no. 1, pp. 60–, Jul. 2019, doi: 10.1186/S40537-019-0197-0.
- [16] Karan, R. Firdaus, and H. Mukhtar, "Transfer Learning dengan CLAHE dan Sharpening filter untuk Deteksi Pneumonia pada Citra X-Ray," *Jurnal Fasilkom*, vol. 16, no. 1, pp. 218–229, May 2026, doi: 10.37859/JF.V16I1.11374.
- [17] L. Alzubaidi *et al.*, "MedNet: Pre-trained Convolutional Neural Network Model for the Medical Imaging Tasks".
- [18] T. Fatima and H. Soliman, "Application of VGG16 Transfer Learning for Breast Cancer Detection," *Information 2025, Vol. 16, Page 227*, vol. 16, no. 3, p. 227, Mar. 2025, doi: 10.3390/INFO16030227.
- [19] H. E. Kim, A. Cosa-Linan, N. Santhanam, M. Jannesari, M. E. Maros, and T. Ganslandt, "Transfer learning for medical image classification: a literature review," *BMC Med. Imaging*, vol. 22, no. 1, p. 69, Dec. 2022, doi: 10.1186/S12880-022-00793-7.
- [20] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *Journal of Big Data 2021 8:1*, vol. 8, no. 1, pp. 53–, Mar. 2021, doi: 10.1186/S40537-021-00444-8.
- [21] Purwono, A. Ma'arif, W. Rahmaniari, H. I. K. Fathurrahman, A. Z. K. Frisky, and Q. M. U. Haq, "Understanding of Convolutional Neural Network (CNN): A Review," *International Journal of Robotics and Control Systems*, vol. 2, no. 4, pp. 739–748, 2022, doi: 10.31763/ijrcs.v2i4.888.
- [22] I. Salehin and D. K. Kang, "A Review on Dropout Regularization Approaches for Deep Neural Networks within the Scholarly Domain," *Electronics 2023, Vol. 12, Page 3106*, vol. 12, no. 14, p. 3106, Jul. 2023, doi: 10.3390/ELECTRONICS12143106.
- [23] I. D. Mienye, T. G. Swart, G. Obaido, M. Jordan, and P. Ilono, "Deep Convolutional Neural Networks in Medical Image Analysis: A Review," *Information 2025, Vol. 16, Page 195*, vol. 16, no. 3, p. 195, Mar. 2025, doi: 10.3390/INFO16030195.
- [24] Y. Li, C. Liu, G. Niu, X. Luo, H. Ma, and Y. Zhao, "Error Detection and Correction of Mismatch Errors in M-Channel TIADCs Based on Genetic Algorithm Optimization," *Electronics 2022, Vol. 11, Page 2366*, vol. 11, no. 15, p. 2366, Jul. 2022, doi: 10.3390/ELECTRONICS11152366.
- [25] J. Lee, W. Wiratama, W. Lee, I. Marzuki, and D. Sim, "Bilateral Attention U-Net with Dissimilarity Attention Gate for Change Detection on Remote Sensing Imageries," *Applied Sciences 2023, Vol. 13, Page 2485*, vol. 13, no. 4, p. 2485, Feb. 2023, doi: 10.3390/APP13042485.
- [26] H. Kwon, Z. Sandhu, Z. Sarwar, and O. M. Andacoglu, "Impact of Medicaid expansion on kidney transplantation in the State Oklahoma," *World J. Transplant.*, vol. 14, no. 3, p. 92981, Sep. 2024, doi: 10.5500/WJT.V14.I3.92981.